

**IMPLEMENTACIÓN DE UN MODELO PARA LA IDENTIFICACIÓN DE  
PARÁSITOS *PLASMODIUM* EN IMÁGENES DE MUESTRAS DE SANGRE  
MEDIANTE LA UTILIZACIÓN DE REDES NEURONALES  
CONVOLUCIONALES**

**SEBASTIAN ZAPATA RUIZ**

**Proyecto de Grado**

**Director Mgtr. Ramiro Andrés Barrios Valencia**

**UNIVERSIDAD TECNOLÓGICA DE PEREIRA  
FACULTAD DE INGENIERÍAS  
INGENIERÍA DE SISTEMAS Y COMPUTACIÓN  
PEREIRA  
2020**

# CONTENIDO

INTRODUCCIÓN.....	4
1. PROBLEMA .....	5
1.1. JUSTIFICACIÓN .....	6
2. OBJETIVOS.....	7
2.1. OBJETIVO GENERAL.....	7
2.2. OBJETIVOS ESPECÍFICOS .....	7
3. ANTECEDENTES TEÓRICOS .....	8
3.1. MALARIA .....	8
3.2. DIAGNÓSTICO DE LA MALARIA.....	9
3.2.1. EXAMINACIÓN MICROSCÓPICA .....	9
3.2.2. <i>RDT: RAPID DIAGNOSTIC TEST</i> .....	9
3.2.3. SEROLOGÍA .....	10
3.3. INTELIGENCIA ARTIFICIAL .....	11
3.4. <i>DEEP LEARNING</i> : APRENDIZAJE PROFUNDO PARA EL RECONOCIMIENTO DE OBJETOS EN IMÁGENES.....	11
3.5. REDES NEURONALES CONVOLUCIONALES .....	12
3.5.1. CONVOLUCIÓN .....	13
3.5.2. NO LINEALIDAD .....	14
3.5.3. SUBMUESTREO .....	14
3.5.4. NORMALIZACIÓN.....	14
3.5.5. CAPAS COMPLETAMENTE CONECTADAS.....	15
3.6. <i>TENSORFLOW</i> .....	15
3.7. <i>TENSORFLOW OBJECT DETECTION API</i> .....	16
4. ACTUALIDAD .....	17
4.1. DIAGNÓSTICO DE LA MALARIA.....	17
4.2. INTELIGENCIA ARTIFICIAL EN EL RECONOCIMIENTO DE PARÁSITOS EN MUESTRAS DE SANGRE .....	17
4.2.1. <i>AUTOMATED BLOOD SMEAR ANALYSIS FOR MOBILE MALARIA DIAGNOSIS</i> , 2014 ..	17
4.2.2. <i>EASYSCANGO</i> , 2017 .....	17
4.2.3. <i>MOMALA</i> , 2017 .....	17

4.2.4. <i>AI SCOPE</i> , 2017 .....	18
5.    MARCO METODOLÓGICO.....	19
5.1.    INVESTIGACIÓN Y ANÁLISIS.....	19
5.2.    ADQUISICIÓN DE DATOS .....	19
5.3.    IMPLEMENTACIÓN DEL MODELO .....	19
5.4.    PRUEBAS.....	19
5.5.    EVALUACIÓN .....	19
6.    DESARROLLO .....	20
6.1.    INVESTIGACIÓN Y ANÁLISIS.....	20
6.2.    ADQUISICIÓN DE DATOS .....	20
6.3.    ANOTACIONES.....	20
6.4.    PREPROCESAMIENTO .....	20
6.5.    MODELO.....	21
6.6.    IMPLEMENTACIÓN .....	21
6.7.    VARIABLES.....	23
6.8.    ENTRENAMIENTO.....	23
6.9.    PRUEBAS.....	24
6.10.    EVALUACIÓN .....	28
7.    CONCLUSIONES .....	31
RECOMENDACIONES.....	32
REFERENCIAS.....	33
ANEXOS.....	36

# INTRODUCCIÓN

El presente proyecto implementa el reconocimiento de parásitos *plasmodium* (Malaria-Paludismo) en imágenes tomadas de muestras de sangre mediante la utilización de métodos computacionales, para este proyecto en concreto se utiliza el modelo de Redes Neuronales Convolucionales (CNN por sus siglas en ingles), un método inspirado en el sistema visual de los mamíferos, caracterizado por dos diferentes tipos de unidades, el reconocimiento de un patrón en una posición específica y el reconocimiento de este patrón en cualquiera de los posibles lugares de un área más amplia.

Para llevar a cabo el reconocimiento de parásitos es necesario contar con un conjunto de datos con imágenes de los parásitos, este reconocimiento es posible gracias a que dichos parásitos tienen características que los diferencian de otros organismos que habitan en la sangre.

Este proyecto se realiza con el interés de crear una herramienta que permita detectar de manera fácil y rápida la enfermedad, debido a que si no se es detectada y tratada oportunamente puede ocasionar la muerte del infectado.

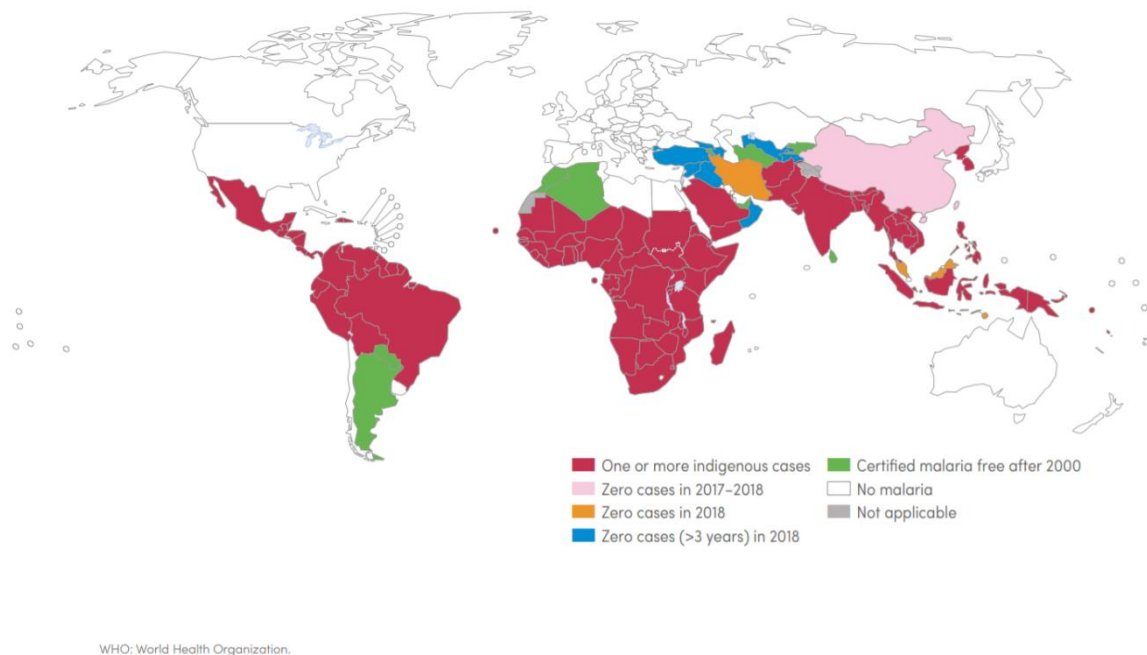
Por otra parte, los métodos de inteligencia artificial son temas de un gran interés académico e investigativo (Rouhiainen, 2018), el proyecto permite explorar las capacidades computacionales para realizar tareas que requerirían un entrenamiento profesional.

Este proyecto se realizó utilizando una interfaz de programación de aplicaciones (API por sus siglas en ingles) de código libre construida en *TensorFlow* (TensorFlow, 2020) que permite la construcción, entrenamiento y despliegue de modelos para la detección de objetos en imagen.

# 1. PROBLEMA

La malaria es un importante problema de salud pública; cerca de la mitad de la población del mundo vive expuesta a esta. (Rugemalila, y otros, 2007) La Organización mundial de la salud (WHO) en el año 2016, estimó cerca de 215 millones de casos clínicos y más de 400 mil muertes. Noventa por ciento de los casos ocurren en África, siendo los niños menores de 5 años y mujeres embarazadas los más vulnerables a la Malaria. Es una de las causas principales del fallecimiento de niños de estas edades, tomando la vida de un niño cada dos minutos.

**Figura 1.** *Malaria heat map*



Fuente: (World Health Organization (WHO), Malaria Report, 2019).

- Se calcula que en 2017 hubo 219 millones de casos de paludismo en 90 países.
- Las muertes por paludismo se mantuvieron en 435.000 en 2017. (World Health Organization (WHO), 2017)
- En 2018, se estimaron 405.000 muertes y 228 millones de casos de malaria en todo el mundo (World Health Organization (WHO), Malaria Report, 2019).

Según el bacteriólogo Alfonso Zapata Arias, de la Universidad Católica de Manizales, se estima que el análisis de muestra sangre de un paciente que se presume con paludismo puede

tardar al menos 10 minutos en la lectura de la placa con la muestra de sangre del respectivo paciente, siendo 215 millones de casos detectados aproximadamente en el año, supone un uso de tiempo en el laboratorio de dicho bacteriólogo de aproximadamente 136 años únicamente en los casos detectados en un año por la WHO, eso sin tener en cuenta los casos negativos que deben analizarse también y que en ciertas ocasiones pueden ser más de una placa para leer por paciente.

El diagnóstico incorrecto también se debe a que el análisis de las placas es un trabajo tedioso, el cual puede producir fatiga y desidia, esto puede provocar error humano al analizar las muestras de sangre.

## 1.1. JUSTIFICACIÓN

La malaria es un organismo unicelular que se aloja en los glóbulos rojos del afectado, posteriormente matándolos en su proceso, el método microscópico es el más utilizado para su diagnóstico, el encargado debe analizar la muestra de sangre de un paciente, la cual debe observarse por campos, debido a que las células son extremadamente pequeñas, en promedio, un bacteriólogo con 35 años de experiencia tarda 10 minutos por muestra, detectar estos parásitos no es una tarea fácil, requiere la total concentración y energía del encargado. Generalmente el encargado del diagnóstico debe analizar varias muestras, el análisis de estas se vuelve tedioso, causando fatiga y desidia, lo que puede generar un error de diagnóstico.

Según la segunda edición de “(WHO) *The Use of Malaria Rapid Diagnostic Tests*” (World Health Organization (WHO), 2006), el diagnóstico incorrecto de la Malaria en un paciente puede resultar probablemente en la muerte de éste, un diagnóstico rápido, preciso y accesible a la detección de parásitos de Malaria tienen un importante rol para la prevención de esta situación.

La WHO menciona que es clave intensificar las inversiones en investigación del paludismo y desarrollo para lograr el primer hito del *EMT (Emergency Medical Teams)*, que es lograr una reducción del 40% de incidencia de casos y mortalidad por paludismo a nivel mundial en comparación con 2015.

Por lo antes expuesto, en el ámbito de la inteligencia artificial, se propone el conocimiento y la posible aplicación de métodos automáticos, semi-automáticos o de ayuda al encargado del diagnóstico, para un análisis más seguro, confiable, rápido y sencillo de estos parásitos.

En la actualidad, existen métodos de reconocimiento de objetos en imágenes mediante el uso de la inteligencia artificial, entre ellos “*Machine Learning*”, “*Deep Learning*”, máquinas de soporte vectorial (*SVM*), redes neuronales, etc. Con los avances en estos campos y la disponibilidad de diversas herramientas, se pueden implementar modelos para el reconocimiento de parásitos en imágenes de muestras de sangre.

El uso adecuado de estas herramientas podría ayudar a disminuir el tiempo utilizado y ayudar al correcto diagnóstico del análisis de muestras de sangre para pacientes de los cuales se presume Malaria.

## **2. OBJETIVOS**

### **2.1. OBJETIVO GENERAL**

Implementación de un modelo para la identificación de parásitos *Plasmodium* en imágenes de muestras de sangre mediante la utilización de redes neuronales convolucionales.

### **2.2. OBJETIVOS ESPECÍFICOS**

- Analizar el funcionamiento de las redes neuronales convolucionales y determinar sus ventajas y desventajas para el reconocimiento de objetos en imágenes.
- Implementar una red neuronal convolucional y probar su funcionamiento con un conjunto de datos de prueba.
- Implementar un método de normalización de imágenes.
- Implementar un conjunto de datos con imágenes de parásitos *Plasmodium*.
- Probar el funcionamiento de la red neuronal convolucional con el conjunto de datos con imágenes de parásitos *Plasmodium*.
- Realizar pruebas sobre el conjunto de datos de parásitos *Plasmodium* utilizando el método de normalización de imágenes.
- Comparar resultados con y sin método de normalización de imágenes.
- Realizar pruebas y validaciones mediante juicio de expertos.

### 3. ANTECEDENTES TEÓRICOS

#### 3.1. MALARIA

El paludismo es causado por parásitos del género *Plasmodium* que se transmiten al ser humano por la picadura de mosquitos hembra infectados del género *Anopheles*, los llamados vectores del paludismo. Hay cinco especies de parásitos causantes del paludismo en el ser humano, si bien dos de ellas - *Plasmodium falciparum* y *Plasmodium vivax* - son las más peligrosas. Se trata de una enfermedad prevenible y curable.

En 2017, *P. falciparum* fue el causante del 99,7% de los casos estimados de paludismo en la Región de África de la OMS, así como de la mayoría de los casos en las regiones de Asia Sudoriental (62,8%), Mediterráneo Oriental (69%) y Pacífico Occidental (71,9%).

*P. vivax* es el parásito predominante en la Región de las Américas, donde es la causa del 74,1% de los casos de paludismo.

La Región de África de la OMS soporta una parte desproporcionada de la carga mundial de paludismo. En 2017, el 92% de los casos y el 93% de los fallecimientos por la enfermedad se produjeron en esta Región.

La financiación total del control y la eliminación del paludismo alcanzó en 2017 una cifra estimada de US\$ 3100 millones. La contribución de los gobiernos de los países endémicos ascendió a US\$ 900 millones, que representan el 28% de los fondos.

El paludismo es una enfermedad febril aguda. En un individuo no inmune, los síntomas suelen aparecer entre 10 y 15 días tras la picadura del mosquito infectivo. Puede resultar difícil reconocer el origen palúdico de los primeros síntomas (fiebre, dolor de cabeza y escalofríos), que pueden ser leves. Si no se trata en las primeras 24 horas, el paludismo por *P. falciparum* puede agravarse, llevando a menudo a la muerte.

Los niños con enfermedad grave suelen manifestar uno o más de los siguientes síntomas: anemia grave, sufrimiento respiratorio relacionado con la acidosis metabólica o paludismo cerebral. En el adulto también es frecuente la afectación multiorgánica. En las zonas donde el paludismo es endémico, las personas pueden adquirir una inmunidad parcial, lo que posibilita la aparición de infecciones asintomáticas. (World Health Organization (WHO), 2018)



## 3.2.DIAGNÓSTICO DE LA MALARIA

### 3.2.1. EXAMINACIÓN MICROSCÓPICA

Consiste en extraer una muestra de sangre del paciente que se extiende como una muestra gruesa o delgada (Healthwise, 2019), está se tiñe con una mancha *Romanovsky* (con mayor frecuencia *Giemsa*) (Horobin & Walter, 1987) y se examina con un objetivo de inmersión en aceite 100X. Los criterios visuales son utilizados para detectar los parásitos de malaria y diferenciarlos cuando es posible entre sus varias especies.

### 3.2.2. RDT: RAPID DIAGNOSTIC TEST

Consiste en extraer una muestra de sangre que se aplica a la almohadilla de muestra en la tarjeta de prueba junto con ciertos reactivos, después de 15 minutos, la presencia de bandas específicas en la ventana de la tarjeta de prueba indica si el paciente está infectado con *plasmodium falciparum* o una de las otras tres especies de malaria humana, sin embargo esta prueba no descarta la necesidad del examen microscópico puesto que podría no detectar algunas infecciones con menor número de parásitos de malaria circulando en el flujo sanguíneo del paciente.

**Figura 2.** BinaxNow Malaria Test.




Fuente: (CDC, 2018)

### 3.2.3. SEROLOGÍA

Se detecta el anticuerpo contra la malaria utilizando la prueba indirecta de anticuerpos fluorescentes (*IFA* por sus siglas en inglés). La prueba *IFA* puede ser utilizada para determinar si un paciente fue infectado con *Plasmodium*. Debido al tiempo requerido para el desarrollo de anticuerpos y también la persistencia de estos, las pruebas serológicas no son prácticas para el diagnóstico de rutina de la malaria aguda, sin embargo, la detección de anticuerpos puede ser útil para:

- Detección de donantes de sangre involucrados en casos de malaria inducida por transfusión cuando la parasitemia del donante puede estar por debajo del nivel detectable del examen de sangre,
- Prueba a un paciente, generalmente de un área endémica, que ha tenido infecciones de malaria repetidas o crónicas por una afección conocida como síndrome de esplenomegalia tropical,
- Prueba a un paciente que ha sido tratado recientemente por malaria, pero en quien se cuestiona el diagnóstico.

**Figura 3.** *IFA test*: El fluorescente indica que el suero del paciente sientro probado contiene anticuerpos que están reaccionando con el antígeno (En este caso, parásitos *Plasmodium falciparum*).



Fuente: (CDC, 2018)

### 3.3. INTELIGENCIA ARTIFICIAL

La inteligencia artificial, para el área de los sistemas informáticos es una máquina o agente ideal racional flexible que percibe su entorno y lleva a cabo acciones que maximicen sus posibilidades de éxito en algún objetivo o tarea (Poole, 2018), la cual será utilizada en este proyecto, como una máquina o agente que imita las funciones “cognitivas” que los humanos asocian con otras mentes humanas, como por ejemplo: "aprender" y "resolver problemas" (Russell & Norvig, 2009).

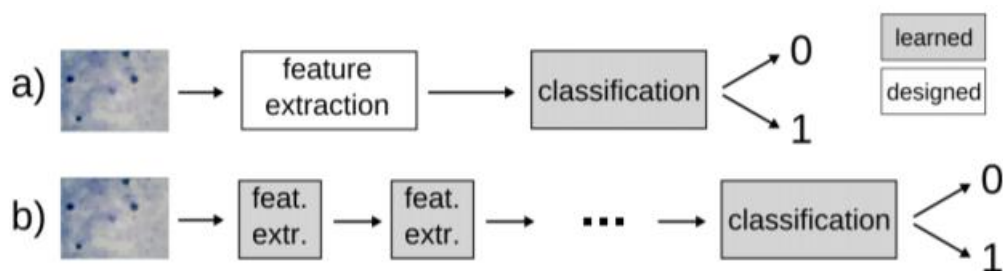
La inteligencia artificial, como objeto de estudio, se divide en una gran cantidad de campos, está no se limita solamente al comportamiento humano, también puede estar inspirada en comportamientos grupales, cómo colonias de hormigas e inclusive en genética (Beni, Wang, & Swarm, 1989). Concretamente para este proyecto se utilizarán redes neuronales convolucionales comúnmente utilizadas para el reconocimiento de objetos en imágenes.

### 3.4. DEEP LEARNING: APRENDIZAJE PROFUNDO PARA EL RECONOCIMIENTO DE OBJETOS EN IMÁGENES

Las técnicas del aprendizaje profundo no solo nos permiten resolver problemas típicos de “*machine learning*” (clasificación en este caso) sino también crear representaciones apropiadas de la información que entra, como se muestra en la **figura 2**. El aprendizaje profundo incluye redes neuronales con múltiples capas ocultas en la cual cada una provee una nueva representación de la información. En este caso utilizamos Redes Neuronales Convolucionales (CNN por sus siglas en ingles).

El éxito de este tipo de redes ha sido comprobado en múltiples ocasiones, algunos de los resultados más representativos han sido obtenidos en la “*ImageNet Large Scale Visual Recognition Challenge (ILSVRC)*” (O. Russakovsky, 2014), donde se han utilizado más de 1,000 diferentes clases de objetos. El modelo propuesto por Krizhevsky *et al* (Krizhevsky, Sutskever, & Hinton, 2012) en la ILSVRC-2012 ha sido tomado frecuentemente como referencia. Esta incluye 5 capas convolucionales seguida por 3 capas completamente conectadas, sin embargo, modelos más profundos han sido utilizados (Szegedy, y otros, 2014).

**Figura 4.** En métodos superficiales, únicamente la clasificación es aprendida (a). En métodos profundos son aprendidas las características y la clasificación (b).



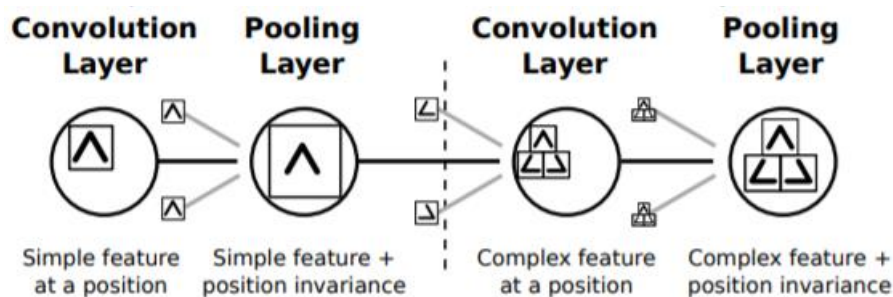
Fuente: (Sánchez, 2015)

### 3.5. REDES NEURONALES CONVOLUCIONALES

El origen de las CNN es el *Fukushima Neocognitron* (Fukushima, 1979). Este modelo está inspirado por el sistema visual de los mamíferos y está caracterizado en dos diferentes tipos de unidades. Las primeras son activadas (después del entrenamiento) cuando un cierto patrón es presentado en cierta posición. El segundo tipo es activado por el mismo patrón, pero en cualquiera de las posibles posiciones de un área más amplia véase la **figura 3**.

Este modelo fue expandido por *LeCun et al* (Y. Lecun, 1998). Para hacer un reconocimiento de fuentes escritas a mano e incluyo todos los aspectos básicos de las CNN:

**Figura 5.** Cada unidad de una capa convolucional aprende características más complejas que la anterior mediante la combinación de características anteriores. Cada capa de agrupación logra la invariancia de posición a partir de entradas de la misma función en ubicaciones diferentes pero cercanas.



Fuente: (Sánchez, 2015)

- Campos receptivos locales: En redes completamente conectadas cada unidad tiene conexiones a cada punto en la capa anterior. Sin embargo, en *CNN's* cada unidad únicamente cubre un subconjunto; en imágenes esto corresponde a un área de la imagen.
- Pesos compartidos: No todas las unidades tienen diferentes pesos. Las unidades de una capa están distribuidas en conjuntos. Cada conjunto compartirá los mismos pesos mientras que cada unidad será aplicada a un área diferente de la capa anterior.
- Submuestreo: La salida de la misma unidad en posiciones cercanas se resume de manera que la ubicación exacta de la característica no es relevante, logrando la invariancia de posición.

Tomando esto en cuenta, el número de parámetros es mucho menor comparado con capas completamente conectadas, debido a la escasa conexión (campos receptivos locales) y los pesos compartidos. Ambos factores reducen la complejidad del modelo y permite entrenar la red con muchos menos datos.

Además, Las CNNs tienen algunos beneficios que las vuelven particularmente buenas para imágenes. Ellas toman la ventaja de la estructura espacial de la imagen como resultado de la receptividad local de campos. Podemos esperar que los píxeles adyacentes se correlacionen y, por lo tanto, las características locales aprendidas tengan sentido, entonces estamos

introduciendo conocimiento previo de la estructura de la entrada de datos: esto no podría llevarse a cabo con redes completamente conectadas. Además de eso, las CNNs logran invarianza a cambios no relevantes en la imagen de entrada como resultado del submuestreo. Como consecuencia, pequeños cambios en la posición de las características no afectan el resultado.

En redes convolucionales encontramos cuatro diferentes componentes que pueden ser vistos como diferentes capas: convolución, no linealidad, normalización y submuestreo. Un conjunto de estados compuestos por estas cuatro capas, son usualmente seguidas por unas capas completamente conectadas que actúan como un modelo de clasificación típico. Estos componentes son descritos abajo.

### 3.5.1. CONVOLUCIÓN

Los pesos compartidos y los campos de recepción local pueden ser implementados como la convolución de la salida de la capa anterior y un filtro. El filtro es una matriz con los pesos que son aprendidos. El resultado de la convolución corresponde a la matriz resultante del producto interno entre el filtro y la sub-matriz de la información de entrada, centrada a cada punto. Un término *bias* es usualmente presentado y es añadido al resultado de la convolución.

Por lo tanto, para el filtro  $f$  de la capa  $l$ , tenemos un conjunto de pesos  $W_{lf}$  de tamaño  $k * k$  y un término *bias*  $b_{lf}$ . Para una matriz de entrada de dimensión dos  $I$  tenemos una salida de dos dimensiones  $O_{lf}$  donde:

**Figura 6.** Función de convolución

$$O_{lf,ij} = b_{lf} + \sum_{m=-\lfloor \frac{k-1}{2} \rfloor}^{\lfloor \frac{k-1}{2} \rfloor} \sum_{n=-\lfloor \frac{k-1}{2} \rfloor}^{\lfloor \frac{k-1}{2} \rfloor} W_{lf,mn} I_{i+m,j+n}$$

Fuente: (Sánchez, 2015)

Algunas veces, en lugar de aplicar el filtro a cada unidad de la capa anterior, es hecho con una zancada (Krizhevsky, Sutskever, & Hinton, 2012). Aparte de este valor, es necesario establecer la cantidad de filtros y el tamaño ( $k$ , que debe ser par). El uso de varias capas convolucionales lleva a una jerarquía de características (las características de una capa están compuestas por características de la anterior).

El uso de al menos dos etapas generalmente mejora el rendimiento de la red (K. Jarrett, 2009).

### 3.5.2. NO LINEALIDAD

Después de cada convolución hay una no linealidad que hace que el modelo sea capaz de resolver un problema de clasificación sin una solución lineal. La selección de la no linealidad ha sido reportada como la decisión con el mayor impacto en el rendimiento (K. Jarrett, 2009).

Aunque  $\tanh()$  se ha utilizado con frecuencia, las unidades lineales rectificadas (*ReLU*) han sido preferidas para grandes conjuntos de datos, ya que son más fáciles de calcular y esto permite entrenar la red más rápido (Krizhevsky, Sutskever, & Hinton, 2012). La *ReLU* se calcula como:  $f(x) = \max(0, x)$ .

### 3.5.3. SUBMUESTREO

Inicialmente, el método de submuestreo consistía en promediar los resultados de las actividades alrededor de una cierta ubicación. Sin embargo, se demostró que tomando el valor máximo (*max-pooling*) sobre esas actividades conduce a mejores resultados para diferentes conjuntos de datos (Scherer, Muller, & Behnke, 2010).

Es necesario determinar el ancho del *kernel* de agrupación (es decir, cuántas unidades han sido resumidas). Un ancho de agrupamiento grande significaría una mayor invarianza, pero podríamos estar perdiendo información útil. También es necesario establecer la superposición entre agrupación de unidades: esto puede mejorar el rendimiento, pero, al mismo tiempo, incrementa el número de unidades que dificultan el entrenamiento del modelo (Scherer, Muller, & Behnke, 2010).

Las capas de agrupamiento (*pooling*) pueden seguir todas o algunas de las capas convolucionales. Por ejemplo, en el modelo de Krizhevsky *et al.* Hay 5 capas convolucionales y solo 3 de capas de agrupamiento (Krizhevsky, Sutskever, & Hinton, 2012).

### 3.5.4. NORMALIZACIÓN

Es común tener algunas capas de normalización (Krizhevsky, Sutskever, & Hinton, 2012) (K. Jarrett, 2009). En el caso de respuestas de normalización local como se menciona en (Krizhevsky, Sutskever, & Hinton, 2012). Se crea competencia entre las actividades de los filtros en la misma posición durante el aprendizaje y obliga a los filtros a aprender a responder a diferentes características. Se calcula después de algunas *ReLU*. Si  $a_i$  y  $b_i$  son las entradas y las salidas de la *ReLU*:

Los parámetros  $k$ ,  $n$ ,  $\alpha$  y  $\beta$  deberían ser encontrados por validación (A. Krizhevsky, 2012). En particular,  $n$  indica el número de filtros que están involucrados en la normalización. Estos están ordenados aleatoriamente en el inicio y los  $n$  filtros adyacentes son usados en cada unidad.

**Figura 7.** Función de normalización

$$b_{x,y}^i = a_{x,y}^i / \left( k + \alpha \sum_{j=\max(0,i-n/2)}^{\min(N-1,i+n/2)} (a_{x,y}^j)^2 \right)^\beta$$

Fuente: (Sánchez, 2015)

### 3.5.5. CAPAS COMPLETAMENTE CONECTADAS

Después de todas las capas convolucionales y de *pooling*, varias capas completamente conectadas pueden ser usadas como un clasificador tradicional. Las conexiones son evaluadas como el producto interno entre todas las salidas de la capa anterior y un conjunto de pesos, seguido por la adición del término *bias*. Después de todas las capas completamente conectadas a excepción de la última, hay una no linealidad como en las capas convolucionales.

## 3.6. TENSORFLOW

Es una librería de software de código abierto para computación numérica usando gráficos de flujos de datos. Fue desarrollado originalmente por el “*Google Brain Team*”.

*TensorFlow* es un sistema para la implementación y desarrollo de modelos de *machine learning* a gran escala (Google Brain Team, 2015), este sistema está capacitado para funcionar en una gran variedad de plataformas, ya sea desde dispositivos con sistemas operativos *Android* o *iOS* hasta sistemas con grandes cantidades de tarjetas gráficas (*GPU*).

Un cálculo de *TensorFlow* es descrito por un grafo dirigido, el cual se compone por un conjunto de nodos. El grafo representa un cálculo de flujo de datos. En un grafo de *TensorFlow*, cada nodo tiene cero o más entradas y cero o más salidas, y estos representan la instanciación de una operación. Valores que fluyen a través de bordes normales en el grafo (de salidas a entradas) son tensores. (Google Brain Team, 2015)

### ***3.7. TENSORFLOW OBJECT DETECTION API***

Es un *framework* de código abierto construido sobre *TensorFlow* que permite fácilmente construir, entrenar y desplegar modelos de detección de objetos. (Google, 2017) (J, y otros, 2017)



## **4. ACTUALIDAD**

### **4.1. DIAGNÓSTICO DE LA MALARIA.**

Según Los Centros para el Control y Prevención de Enfermedades (CDC, 2018) el método de diagnóstico catalogado como “El estándar de oro” en los laboratorios de Estados Unidos sigue siendo la examinación microscópica para la confirmación de malaria, la cual

Como alternativa, se encuentra la prueba de diagnóstico rápida (*RDT: Rapid Diagnostic Test*) que detecta antígenos específicos de la malaria en la sangre de una persona.

Y menos común pero también es utilizado en algunos casos es el *IFA test*.

### **4.2. INTELIGENCIA ARTIFICIAL EN EL RECONOCIMIENTO DE PARÁSITOS EN MUESTRAS DE SANGRE**

#### **4.2.1. *AUTOMATED BLOOD SMEAR ANALYSIS FOR MOBILE MALARIA DIAGNOSIS*, 2014**

El modelo propuesto (Quinn, Andama, Munabi, & Kiwanuka, 2020) clasifica parches de 50x50 píxeles determinando si contienen o no el parásito. Está compuesto por dos etapas: extracción de características y clasificación. Primero, los parches son organizados en diferentes niveles. Para cada uno de los parches un conjunto de formas características es extraído tales como elongación, irregularidad y perímetro. Las características son entonces usadas para entrenar árboles extremadamente aleatorios (Geurts, Ernst, & Wehenkel, 2020), que son un caso particular de un bosque aleatorio (Yiu, 2019).

#### **4.2.2. *EASYSCANGO*, 2017**

*EasyScanGo* (Motic Europe, 2020) es un microscopio con inteligencia artificial incorporada para combatir el esparcimiento de la malaria resistente y asistir en el manejo de los casos. Usando un software personalizado de reconocimiento de imágenes, *EasyScanGo* es capaz de identificar y contar parásitos de malaria en una muestra de sangre en tan solo 20 minutos. (Global Good, Motic, 2020)

#### **4.2.3. *MOMALA*, 2017**

*Momala* (Momala, 2020) es un método diseñado para conseguir que las personas con presunción de malaria sean diagnosticadas rápidamente y a un costo mínimo, usando un *smartphone* y un microscopio, la aplicación *Momala* usa un algoritmo para detectar la

presencia de parásitos de malaria en placas regulares con muestras de sangre, esencialmente digitalizando el técnico de laboratorio. Al adjuntar la cámara del teléfono al ocular del microscopio, se fotografía la muestra de sangre y posteriormente la aplicación la analiza sin la necesidad de que el *smartphone* esté conectado a la internet. Hasta ahora la aplicación puede identificar los tres tipos de parásitos más comunes en Kenia: *P. falciparum*, *P. ovale* y *P. malariae*.

#### **4.2.4. *AI SCOPE*, 2017**

*Ai Scope* realiza automáticamente todo el proceso de diagnóstico de enfermedades como malaria, tuberculosis y parásitos intestinales sin la necesidad de personal médico entrenado, este microscopio de *hardware* libre está diseñado para ser económico, portable y fácil de construir ya sea con una sierra o un cortador de láser.

El software, está siendo desarrollado con *Python* y *TensorFlow*; este localiza microorganismos usando la misma tecnología que las redes neuronales utilizan para reconocer objetos y rostros.

## **5. MARCO METODOLÓGICO**

### **5.1. INVESTIGACIÓN Y ANÁLISIS**

Investigación y análisis de redes neuronales convolucionales, características del conjunto de datos necesario y herramientas para la implementación de modelos de redes neuronales convolucionales.

### **5.2. ADQUISICIÓN DE DATOS**

Implementación del conjunto de datos necesario para el proyecto, así mismo como el preprocesamiento necesario para el entrenamiento del modelo a implementar.

### **5.3. IMPLEMENTACIÓN DEL MODELO**

Implementar una red neuronal convolucional y probar su funcionamiento.

Consideración de métodos de normalización de imágenes para el conjunto de datos, determinar si pueden mejorar los resultados de la red neuronal, es decir, mejorar la probabilidad en el reconocimiento de objetos.

### **5.4. PRUEBAS**

Probar el funcionamiento de la red neuronal implementada con imágenes de parásitos *plasmodium*.

Las pruebas consistirán en dar imágenes a la red, de muestras de sangre con presencia de parásitos *plasmodium*, para que esta haga el respectivo reconocimiento. Se tendrá en cuenta el tiempo que le toma a la red realizar el reconocimiento y mostrar en una nueva imagen dónde detectó los parásitos, y la respectiva probabilidad de que el objeto reconocido sea un parásito, posteriormente realizar un recuento de la cantidad de parásitos detectados.

### **5.5. EVALUACIÓN**

Comparar resultados de la red neuronal con resultados de un experto en el campo (Bacteriología).

## 6. DESARROLLO

### 6.1. INVESTIGACIÓN Y ANÁLISIS

Para la implementación de la red neuronal convolucional se tuvieron en cuenta el *framework* “Caffe” (Caffe, 2019) y “TensorFlow”. Para este proyecto se eligió *TensorFlow* ya que este cuenta con una *API* para la creación de modelos de redes neuronales convolucionales de forma rápida y sencilla, además de esto cuenta con una gran cantidad de modelos pre-entrenados lo que permite crear nuevos modelos a partir de estos, así la etapa de entrenamiento puede realizarse en menor tiempo y en la etapa de implementación ya se tiene un modelo de red neuronal funcional.

### 6.2. ADQUISICIÓN DE DATOS

Para este proyecto, las imágenes de muestras de sangre con presencia de parásitos *Plasmodium* fueron obtenidas de *AI Research: Artificial Intelligence and Data Science* de la universidad *Makerere*, Uganda (Makerere University, Uganda, 2020). Las imágenes fueron obtenidas fijando un smartphone de bajo costo con sistema operativo *Android* (*ZTE Blade*) a un microscopio *Brunel SP150*, un hardware fácil de obtener en las zonas endémicas de la enfermedad, esto con el objetivo de hacer el sistema practico para ser aplicado en estas zonas.

Los conjuntos de imágenes fueron tomados de muestras de gota gruesa de 133 individuos, usando una magnificación de 1000x.

Este conjunto de datos está compuesto por 1182 imágenes de muestras de sangre en gota gruesa.

### 6.3. ANOTACIONES

Dicho conjunto de datos contiene anotaciones en cada una de las imágenes que consisten en cajas delimitadoras alrededor de cada parasito, estas cajas delimitadoras fueron anotadas mediante la utilización del software *LabelImg* (Tzutalin, 2020). Un equipo de cuatro técnicos de laboratorio experimentados fueron los encargados de redondear cada uno de los parásitos contenidos en las imágenes, de esta manera se registraron 7245 parásitos en el conjunto de imágenes.

Dicho conjunto de datos se encuentra normalizado por el tamaño de las imágenes, cada una de un tamaño de 750x750 pixeles.

### 6.4. PREPROCESAMIENTO

El conjunto de datos obtenido ya se encontraba normalizado y con las anotaciones necesarias para el entrenamiento del modelo, por lo tanto, no fue necesario realizar ningún preprocesamiento para llevar a cabo la implementación de este. Sin embargo, resultados de

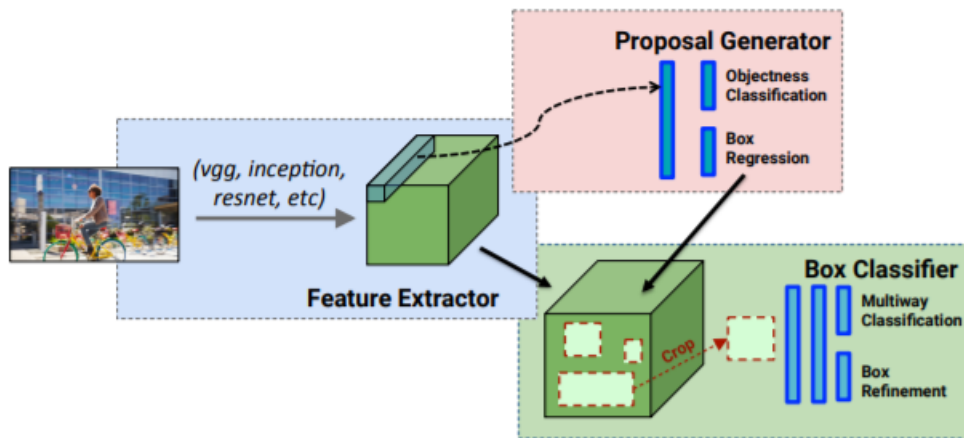
diferentes preprocesamientos de imágenes sobre modelos de reconocimiento de parásitos *plasmodium* pueden encontrarse en *Erik et al* (Engelhardt & Jäger, 2019).

## 6.5. MODELO

*Transfer learning* o transferencia de aprendizaje es un método donde un modelo desarrollado para una tarea es utilizado como el punto de inicio para el modelo de una segunda tarea. (Brownlee, 2017)

Para este proyecto se tomó como punto de partida el modelo *Faster R-CNN Inception v2 (COCO)* (Huang, y otros, 2017) previamente entrenado por *TensorFlow*.

**Figura 8.** Etapas del modelo *Faster R-CNN*



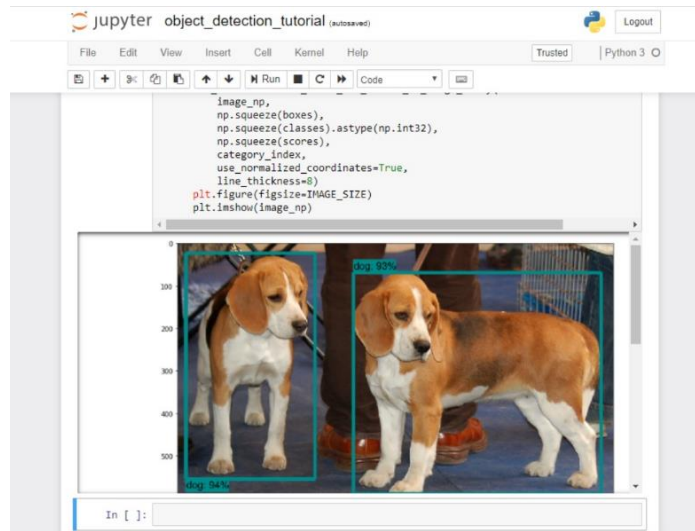
Fuente: (J, y otros, 2017)

## 6.6. IMPLEMENTACIÓN

Para la implementación del *TensorFlow Object Detection API* se siguieron los pasos descritos en (Evan, 2019).

Una vez implementado el Object Detection API se comprobó el funcionamiento, ejecutando el código de prueba provisto por *TensorFlow*, utilizando como conjunto de datos de prueba imágenes de perros (**Figura 9**).

**Figura 9. Prueba API.**



Fuente: Propia.

Posteriormente se creó el mapa de etiquetas, el cual relaciona el objeto a detectar definiéndole un identificador numérico, para este caso se utilizó como etiqueta *plasmodium* para representar parásitos *P. falciparum*, de la siguiente manera:

```
Ítem {  
    Id: 1  
    Name: 'plasmodium'  
}
```

Para configurar el entrenamiento se modificó el “*object detection training pipeline*”, el cual define que modelo y que parámetros serán utilizados para el entrenamiento, allí se modificó:

- El número de clases que se quiere identificar, en este caso 1 clase (*plasmodium*),
- El “*Checkpoint*” el cual hace referencia desde que punto anterior se quiere reentrenar el nuevo modelo, en este caso el obtenido con el modelo *Faster R-CNN*,
- Las fuentes o “*path*” que apuntan a los *TfRecords* generados y el mapa de etiquetas para el proyecto.

Además de lo modificado, para el entrenamiento se realizaron pruebas con el resto de la configuración inicial, la cual debió ser modificada debido a la capacidad del hardware con el que se realizó dichas pruebas, teniendo que reducir el *batch\_size* a el valor de 1, el cual hace referencia a la cantidad de valores de datos que se introducen en el modelo.


## 6.7. VARIABLES

- Probabilidad: Porcentaje que determina la probabilidad que sea un parásito *plasmodium*.
- *Loss* (Pérdida): Determina que tan lejos se desvían los valores predichos de los valores reales en el dato de entrenamiento, el objetivo es reducir la variable de pérdida al mínimo posible, de esto se trata el entrenamiento.
- *Learning Rate* (Tasa de aprendizaje): La tasa de aprendizaje es un hiper parámetro que controla que tanto se ajustan los pesos de la red con respecto al gradiente de pérdida.
- *Step* (pasos): Iteración.

## 6.8. ENTRENAMIENTO

El entrenamiento para la construcción del modelo consto de 26.103 pasos para un total de 6 horas 39 minutos y 59 segundos, este realizado en una *GPU Nvidia GeForce 940M* (2 GB) y una memoria *RAM* de 8 GB. Los resultados obtenidos pueden observarse en **ANEXOS tabla 1**.

**Figura 10.** Grafica *Total Loss*




Fuente: Propia.

## 6.9. PRUEBAS

- **Prueba 1.**

**Figura P1.** Imagen para reconocimiento.




Fuente: (Quinn, y otros, 2016)

**Resultado:**

Tiempo: 10.57 segundos.

Cantidad de parásitos detectados: 4.

**Figura R1.** Imagen posterior al reconocimiento.




Fuente: Propia.



- **Prueba 2.**

**Figura P2.** Imagen para reconocimiento.




Fuente: (Quinn, y otros, 2016)

**Resultado:**

Tiempo: 10.16 segundos.

Cantidad de parásitos detectados: 11.


**Figura R2.** Imagen posterior al reconocimiento.



Fuente: Propia.

- **Prueba 3.**

**Figura P3.** Imagen para reconocimiento.




Fuente: (Quinn, y otros, 2016)

**Resultado:**

Tiempo: 10.15 segundos.

Cantidad de parásitos detectados: 2.


**Figura R3.** Imagen posterior al reconocimiento



Fuente: Propia.

- **Prueba 4.**

**Figura P4.** Imagen para reconocimiento.




Fuente: (Quinn, y otros, 2016)

**Resultado:**

Tiempo: 10.18 segundos.

Cantidad de parásitos detectados: 1.

**Figura R4.** Imagen posterior al reconocimiento.




Fuente: Propia.

## 6.10. EVALUACIÓN

Con el apoyo del Bacteriólogo Alfonso Zapata, se realizó un diagnóstico de cada una de las pruebas mencionadas anteriormente, los resultados obtenidos fueron:

- **Prueba 1**

**Figura E1.** Imagen diagnosticada por profesional vs Reconocimiento de la red.




Fuente: Propia.

**Comentarios:**

Según el profesional, faltó una detección de parasito *plasmodium* por parte de la red, en los demás concuerda.

- **Prueba 2**

**Figura E2.** Imagen diagnosticada por profesional vs Reconocimiento de la red.



Fuente: Propia.


### Comentarios:

Según el profesional, la detección por parte de la red del parásito con un 73% de probabilidad no puede diagnosticarse como parásito ya que la forma de este no está bien definida.

El profesional detectó un parásito más, el cual tiene la forma del anillo, característica de este parásito en un azul tenue.

- **Prueba 3**

**Figura E3.** Imagen diagnosticada por profesional vs Reconocimiento de la red.



Fuente: Propia.


### Comentarios:

En esta prueba, el profesional detectó dos adicionales, supone que la red no pudo detectar la sombra del anillo del parásito.

También comenta el profesional que el detectado por la red en la parte inferior si es un parásito *plasmodium* que pasó por alto en el diagnóstico.

- **Prueba 4**

**Figura E4.** Imagen diagnosticada por profesional vs Reconocimiento de la red.



Fuente: Propia.

**Comentarios:**

Los resultados concuerdan.

## 7. CONCLUSIONES

Considerando la importancia del diagnóstico de la malaria y la falta de recursos y técnicos de laboratorio entrenados en países endémicos de dicha enfermedad, las técnicas para reconocimiento de objetos orientadas al diagnóstico de esta enfermedad pueden ser de gran ayuda.

Las *CNN*'s conllevan a considerables mejoras en la detección de objetos en imágenes, arrojando mejores predicciones que otros métodos que se aplicaron sobre este mismo conjunto de datos (Quinn, Andama, Munabi, & Kiwanuka, 2020) y que otras redes no convolucionales (Sánchez, 2015).

Para la detección de parásitos en una pequeña porción de una imagen la utilización de métodos de aprendizaje profundo, en este caso redes neuronales convolucionales (*CNN*), demostró ser útil, clasificando parásitos en un intervalo de probabilidad de 63% hasta 96% de confiabilidad.

Analizando los resultados de (Engelhardt & Jäger, 2019) se puede observar que los métodos de preprocesamiento de imágenes generan una mejora en el entrenamiento y evaluación de redes neuronales convolucionales, sin embargo muy pequeña, por ejemplo, en este proyecto el método con mejores resultados (*CLAHE* (S. M. Pizer, 1987)) solo tuvo un impacto positivo de 0,6-1% con respecto a los resultados sin normalización. Por lo tanto, se requiere mayor investigación para determinar si vale la pena añadir la complejidad y el tiempo necesario para estos con el fin de obtener pequeñas mejoras en los análisis.

Tras escuchar el informe del Bacteriólogo Alfonso Zapata Arias, graduado de la Universidad Católica de Manizales, Colombia. Para un diagnóstico rápido de las imágenes, se tardó 40 segundos en promedio para cada una de las imágenes, en el área de la bacteriología, afirma que este proceso se llama tamizaje, el cual se realiza para determinar si una placa contiene o no parásitos y el tipo de parásitos que se encuentran, en este caso *P. falciparum*.

Comenta el bacteriólogo que le ve gran utilidad a la red para realizar dicho proceso (Tamizaje), ya que lo realiza rápidamente (Alrededor de 10 segundos), sin embargo, comenta que para poder arrojar un diagnóstico es necesario revisar con detenimiento las imágenes ya que como se mostró en la evaluación, la red no detectó algunos de los parásitos y marcó uno que no lo era.

Afirma el bacteriólogo, que, al conocer el tamizaje de la muestra, el profesional ahorra mucho tiempo a la hora de analizar dicha muestra.

Podemos concluir entonces que el reconocimiento de parásitos utilizando redes neuronales convolucionales puede ser de gran utilidad para los profesionales encargados del diagnóstico y que con un conjunto de imágenes más extenso y un mayor entrenamiento del modelo pueden obtenerse mejores resultados.

## RECOMENDACIONES

El conjunto de datos utilizado para este proyecto fue construido mediante la utilización de un *smartphone* de bajo costo *ZTE Blade*, por lo tanto, la calidad de las imágenes es baja, lo que hace difícil el diagnóstico visual de un técnico de laboratorio, un mejor conjunto de datos, es decir, imágenes de mejor calidad podría generar mejores resultados al realizar una evaluación de juicio de un experto. Así mismo, una mayor cantidad de imágenes y más variedad en la forma de aparición de los parásitos podría arrojar mejores resultados.



## REFERENCIAS

- A. Krizhevsky, I. S. (13 de Octubre de 2012). *ImageNet Classification with Deep Convolutional*. Obtenido de ImageNet Classification with Deep Convolutional:  
<https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>
- Beni, G., Wang, & Swarm, J. (1989). *Intelligence in Cellular Robotic Systems*. Tuscany, Italy: NATO Advanced Workshop on Robots and Biological Systems.
- Brownlee, J. (20 de Diciembre de 2017). *Machine Learning Mastery*. Obtenido de Machine Learning Mastery Web site: <https://machinelearningmastery.com/transfer-learning-for-deep-learning/>
- Caffe. (12 de Febrero de 2019). *Caffe*. Obtenido de Caffe Web site:  
<https://caffe.berkeleyvision.org/>
- CDC. (23 de Julio de 2018). *Centers for Disease Control and Prevention*. Obtenido de Centers for Disease Control and Prevention:  
[https://www.cdc.gov/malaria/diagnosis\\_treatment/diagnostic\\_tools.html](https://www.cdc.gov/malaria/diagnosis_treatment/diagnostic_tools.html)
- Engelhardt, E., & Jäger, S. (7 de Junio de 2019). *DiVA*. Obtenido de An evaluation of image preprocessing for classification of Malaria parasitization using convulotional neural networks: <http://www.diva-portal.org/smash/get/diva2:1354567/FULLTEXT01.pdf>
- Evan. (12 de Octubre de 2019). *Github EdgeElectronics*. Obtenido de Github EdgeElectronics TensorFlow O. detection Repository: <https://github.com/EdgeElectronics/TensorFlow-Object-Detection-API-Tutorial-Train-Multiple-Objects-Windows-10>
- Fukushima, K. (1979). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics vol 36*, 193-202.
- Geurts, P., Ernst, D., & Wehenkel, L. (14 de Enero de 2020). *citeseerx*. Obtenido de citeseerx:  
<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.65.7485&rep=rep1&type=pdf>
- Global Good, Motic. (14 de Enero de 2020). *moticeasyscan*. Obtenido de moticeasyscan:  
<https://moticeasyscan.com/wp-content/uploads/2019/10/Press-Release-EasyScanGo.pdf>
- Google. (15 de Junio de 2017). *github*. Obtenido de github:  
[https://github.com/tensorflow/models/tree/master/research/object\\_detection](https://github.com/tensorflow/models/tree/master/research/object_detection)
- Google Brain Team. (9 de Noviembre de 2015). *googleapis*. Obtenido de googleapis:  
<https://storage.googleapis.com/pub-tools-public-publication-data/pdf/45166.pdf>
- Healthwise. (9 de Junio de 2019). *NorthShore*. Obtenido de NorthShore:  
<https://www.northshore.org/healthresources/encyclopedia/encyclopedia.aspx?DocumentHwid=hw118744&Lang=es-us>

- Horobin, R., & Walter, K. J. (1987). Understanding Romanowsky staining. I: The Romanowsky-Giemsa effect in blood smears. *Histochemistry* 86, 6-331.
- Huang, J., Rathod, V., Sun, C., Zhu, M., Korattikara, A., Fathi, A., . . . Murphy, K. (25 de Abril de 2017). *arXiv*. Obtenido de arXiv Web site: <https://arxiv.org/pdf/1611.10012.pdf>
- J, H., V, R., C, S., M, Z., A, K., A, F., . . . K, M. (2017). *Speed/accuracy trade-offs for modern convolutional object detectors*. Honolulu, Hawaii: CVPR.
- K. Jarrett, K. K. (2009). What is the best architecture for object recognition? *Computer Vision and Pattern Recognition, 2009 IEEE 12th International Conference*, 2146-2153.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (13 de Octubre de 2012). *ImageNet Classification with Deep Convolutional*. Obtenido de ImageNet Classification with Deep Convolutional: <https://papers.nips.cc/paper/4824-imagenet-classification-with-deep-convolutional-neural-networks.pdf>
- Makerere University, Uganda. (14 de Enero de 2020). *AI Research*. Obtenido de AI Research: <http://air.ug/microscopy/>
- MedlinePlus. (6 de Enero de 2020). *MedlinePlus*. Obtenido de MedlinePlus: <https://medlineplus.gov/spanish/ency/article/000621.htm>
- Momala. (14 de Enero de 2020). *Momala*. Obtenido de Momala: <https://momala.org/malaria-diagnosis/>
- Motic Europe. (14 de Enero de 2020). *Motic*. Obtenido de Motic: <https://moticeasyscan.com/easyscango/>
- O. Russakovsky, J. D.-F. (18 de Agosto de 2014). *image-net*. Obtenido de image-net: <http://image-net.org/challenges/LSVRC/2014/>
- Poole, D. (13 de Junio de 2018). *Computational Intelligence: A Logical Approach*. Obtenido de Computational Intelligence: A Logical Approach: <http://people.cs.ubc.ca/~poole/ci/ch1.pdf>
- Quinn, J., Andama, A., Munabi, I., & Kiwanuka, F. (14 de Enero de 2020). *air*. Obtenido de air: <http://air.ug/~jqinn/papers/AutomatedMalariaDiagnosisChapter.pdf>
- Quinn, J., Nakasi, R., Mugagga, P., Byanyima, P., Lubega, W., & Andama, A. (2016). Deep Convolutional Neural Networks for Microscopy-Based Point of Care Diagnostics. *Proceedings of the International Conference on Machine Learning for Health Care, Journal of Machine Learning Research W&C track, Volume 56*.
- Rouhiainen, L. (15 de Agosto de 2018). *Lasse Rouhiainen*. Obtenido de Lasse Rouhiainen web site: <https://www.lasserouhiainen.com/9-reasons-why-artificial-intelligence-is-important-now/>
- Rugemalila, J. B., T, O. A., Ogundahunsi, Stedman, T. T., L, W., & Kilama. (1 de Diciembre de 2007). *ncbi*. Obtenido de ncbi: <https://www.ncbi.nlm.nih.gov/books/NBK1681/>

- Russell, S. J., & Norvig, P. (2009). *Artificial intelligence: a modern approach (en inglés) (3.ª edición)*. Upper Saddle River, N.J.: Prentice Hall.
- S. M. Pizer, E. P. (1987). Adaptive Histogram Equalization and Its Variations. *Computer Vision, Graphics, and Image Processing* 39, 355-368.
- Sánchez, C. S. (1 de Septiembre de 2015). *Docplayer*. Obtenido de Docplayer: <http://docplayer.net/27777030-Deep-learning-for-identifying-malaria-parasites-in-images.html>
- Scherer, D., Muller, A., & Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. *Proceedings of the 20th International Conference on Artificial Neural Networks: Part III*, 92-101.
- Szegedy, C., Liu, W., Jia, P., Sermanet, Reed, S., Anguelov, D., . . . Rabinovich, A. (17 de Septiembre de 2014). *Going deeper with convolutions*. Obtenido de Going deeper with convolutions: <https://arxiv.org/abs/1409.4842>
- TensorFlow. (1 de Enero de 2020). *TensorFlow*. Obtenido de TensorFlow: <https://www.tensorflow.org/>
- Tzutalin. (14 de Enero de 2020). *Tzutalin*. Obtenido de Tzutalin: <https://tzutalin.github.io/labellmg/>
- Wikipedia. (12 de Enero de 2020). *Wikipedia*. Obtenido de Wikipedia: [https://es.wikipedia.org/wiki/Inteligencia\\_artificial](https://es.wikipedia.org/wiki/Inteligencia_artificial)
- World Health Organization (WHO). (23 de Enero de 2006). *who*. Obtenido de who: [http://www.wpro.who.int/malaria/NR/rdonlyres/44C556B8-0E04-4D26-BC1D-D00D2743B2C0/0/TheuseofMalariaRDTs\\_2ndedition\\_2006.pdf?ua=1](http://www.wpro.who.int/malaria/NR/rdonlyres/44C556B8-0E04-4D26-BC1D-D00D2743B2C0/0/TheuseofMalariaRDTs_2ndedition_2006.pdf?ua=1)
- World Health Organization (WHO). (29 de Noviembre de 2017). *who*. Obtenido de who: <http://www.who.int/malaria/media/world-malaria-report-2017/es/>
- World Health Organization (WHO). (11 de Junio de 2018). *who*. Obtenido de who: <https://www.who.int/es/news-room/fact-sheets/detail/malaria>
- World Health Organization (WHO), Malaria Report. (4 de Diciembre de 2019). *who*. Obtenido de who: <https://www.who.int/malaria/media/world-malaria-report-2019/es/>
- Y. Lecun, L. B. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE, vol. 86, no. 11*, 2278-2324.
- Yiu, T. (12 de Junio de 2019). *Towards Data Science*. Obtenido de Towards Data Science: <https://towardsdatascience.com/understanding-random-forest-58381e0602d2>

## ANEXOS

**Tabla 1.** Resultados de entrenamiento.

<i>Step</i>	<i>Time (s)</i>	<i>Learning Rate</i>	<i>Total Loss</i>
0	0	2E+16	1,35549E+16
119	9,99522E+15	2E+16	1,56162E+15
251	1,09169E+16	2E+16	4,057E+16
382	1,09169E+16	2E+16	1,03755E+16
513	1,09987E+16	2E+16	7,24465E+15
644	1,09176E+16	2E+16	1,30753E+16
775	1,08344E+16	2E+16	4,13576E+15
906	1,10001E+14	2E+16	2,57871E+15
1037	1,09164E+16	2E+16	1,2901E+16
1168	1,09163E+16	2E+16	8,96988E+15
1299	1,09169E+16	2E+16	7,85811E+15
1430	1,09161E+14	2E+16	5,6427E+15
1561	1,09158E+16	2E+16	7,27838E+15
1692	1,08349E+16	2E+16	3,30339E+16
1821	1,08326E+16	2E+16	9,55026E+15
1950	1,07501E+16	2E+16	6,42035E+15
2080	1,07497E+16	2E+16	4,67423E+15
2994	1,09166E+16	2E+16	6,45356E+15
3123	1,07502E+16	2E+16	3,95005E+16
3253	1,08331E+16	2E+16	6,04206E+15
3899	1,07498E+16	2E+16	9,79946E+15
4028	1,08305E+16	2E+16	7,95048E+15
4158	1,08361E+16	2E+16	7,72749E+15
4290	1,09168E+16	2E+16	8,74149E+15
4420	1,09165E+16	2E+16	8,60117E+15
4552	1,09167E+16	2E+16	8,40022E+15
5595	1,09167E+16	2E+16	7,88354E+15
5726	1,09167E+16	2E+16	6,68821E+15
5856	1,09128E+16	2E+16	6,113E+15
5986	1,08283E+16	2E+16	8,69731E+15
6117	1,08422E+16	2E+16	5,14844E+15
6248	1,09167E+16	2E+16	4,25193E+15
6378	1,09166E+16	2E+16	4,69644E+15
6510	1,09165E+16	2E+16	6,60357E+14
7817	1,09165E+16	2E+16	6,86166E+15
7947	1,0916E+16	2E+16	7,83736E+15

8077	1,08323E+16	2E+16	9,28737E+15
8208	1,08351E+16	2E+16	4,9468E+16
8338	1,09165E+16	2E+16	5,66477E+15
8470	1,09168E+16	2E+16	8,54791E+15
8600	1,09164E+16	2E+16	9,69643E+15
8731	1,08332E+16	2E+16	8,67184E+15
8860	1,08337E+16	2E+16	9,0167E+14
8990	1,08327E+15	2E+16	5,50506E+15
9121	1,0833E+16	2E+16	2,4703E+15
9251	1,09077E+16	2E+16	2,34732E+15
10427	1,09166E+16	2E+16	5,85135E+15
10558	1,08326E+16	2E+16	6,65629E+15
10688	1,09169E+16	2E+16	7,90825E+15
10819	1,09174E+16	2E+16	3,52719E+14
10951	1,0916E+16	2E+16	6,9391E+15
11081	1,08327E+16	2E+16	6,03408E+15
11211	1,09186E+16	2E+16	3,83169E+16
11342	1,0832E+16	2E+16	1,03258E+16
11472	1,0918E+16	2E+16	9,12215E+15
11602	1,08508E+15	2E+16	3,35572E+16
11733	1,08971E+16	2E+16	5,59786E+14
11863	1,08343E+16	2E+16	6,6405E+15
19568	1,09171E+15	2E+16	4,80855E+15
19698	1,09167E+16	2E+16	7,28518E+15
19829	1,09164E+16	2E+16	1,02801E+16
19960	1,08335E+16	2E+16	4,21622E+16
20090	1,09157E+15	2E+16	2,30216E+16
20222	1,09168E+16	2E+16	1,25643E+15
20352	1,09182E+16	2E+16	3,25871E+14
21920	1,08332E+16	2E+16	2,20492E+16
22051	1,09158E+16	2E+16	5,14227E+15
22181	1,09181E+16	2E+16	3,95359E+16
22311	1,08328E+16	2E+16	5,13322E+15
22442	1,09173E+15	2E+16	4,41154E+15
22573	1,09166E+16	2E+16	3,27172E+16
22704	1,0915E+16	2E+16	2,75621E+15
22835	1,09171E+15	2E+16	4,69947E+15
22966	1,08331E+16	2E+16	5,78121E+15
23096	1,09175E+16	2E+16	6,35885E+15
23227	1,08323E+16	2E+16	7,42428E+12
23357	1,0918E+16	2E+16	1,88361E+16

24925	1,08347E+15	2E+16	6,85019E+15
25056	1,0916E+16	2E+16	3,56918E+16
25187	1,09164E+16	2E+16	1,56452E+16
25318	1,0916E+16	2E+16	9,7983E+15
25450	1,09171E+16	2E+16	8,70608E+15
25579	1,08326E+16	2E+16	7,66192E+15
25710	1,0918E+16	2E+16	7,50668E+15
25841	1,09088E+16	2E+16	4,78602E+16
25972	1,08416E+16	2E+16	5,16983E+15
26103	1,09154E+15	2E+16	5,62076E+15